

УНИВЕРЗИТЕТ У БЕОГРАДУ
- МАШИНСКИ ФАКУЛТЕТ -
БРОЈ: 3127/2
ДАТУМ: 11.12.2014.

На основу захтева др Бојана Бабића, редовног професора Машинског факултета Универзитета у Београду, бр. 3127/1 од 03.12.2014. године и чл. 63. Статута Машинског факултета, Наставно-научно веће Машинског факултета на седници од 11.12.2014. године, донело је следећу

ОДЛУКУ

Да се за рецензенте Техничког решења под насловом: „РЕПРОДУКЦИЈА КОМПЛЕКСНИХ ТРАЈЕКТОРИЈА МОБИЛНОГ РОБОТА НА БАЗИ БИОЛОШКИ ИНСПИРИСАНИХ АЛГОРИТАМА“ чији су аутори: др Марко Митић, истраживач сарадник, др Најдан Вуковић, научни сарадник, асист. Милица Петровић, дипл.инж.маш., асист. Јелена Петронијевић, дипл.инж.маш., проф. др Зоран Миљковић и мр Иван Лазаревић, дипл.инж.маш., именују:

- доц. др Радиша Јовановић, Универзитет у Београду, Машински факултет
- др Мирко Ђалић, ванр. проф., Универзитет у Крагујевцу – Факултет за машинство и грађевинарство у Краљеву

Одлуку доставити: Министарству просвете, науке и технолошког развоја РС, рецензентима и архиви Факултета ради евиденције.



² Д Е К А Н
МАШИНСКОГ ФАКУЛТЕТА


Проф. др Милорад Милованчевић

Репродукција комплексних трајекторија мобилног робота на бази биолошки инспирисаних алгоритама

Марко Митић¹, Најдан Вуковић², Милица Петровић³, Јелена Петронијевић⁴,
Зоран Миљковић⁵, Иван Б. Лазаревић⁶

1. ОБЛАСТ НА КОЈУ СЕ ТЕХНИЧКО РЕШЕЊЕ ОДНОСИ

Техничко решење припада области машинства и директно се односи на решавање проблема управљања интелигентног мобилног робота применом емпиријске управљачке теорије на бази биолошки инспирисаних алгоритама оптимизације и машинског учења демонстрацијом, и може се уврстити у напредне производне технологије. Нова метода представља решење проблема машинског учења и репродукције комплексних трајекторија нехолономног мобилног робота. Имплементирана су три независна метахеуристичка алгорита теорије ројева: (i) алгоритам оптимизације колонијом свитаца (енгл. *Firefly Algorithm-FA*), (ii) алгоритам оптимизације ројем честица (енгл. *Particle Swarm Optimization-PSO*), и (iii) алгоритам оптимизације колонијом слепих мишева (енгл. *Bat Algorithm-BA*). Управљачке команде мобилног робота за репродукцију више трајекторија жељеног облика меморисане су у модулу демонстрација, док модул машинског учења подразумева имплементацију поменутих метода оптимизације у циљу одређивања оптималне трајекторија робота. Експериментални резултати су показали да алгоритам оптимизације колонијом свитаца представља најбоље решење поменутог проблема, као и да се сви наведени биолошки инспирисани алгоритми могу успешно користити за учење и репродукцију различитих комплексних трајекторија.

2. ТЕХНИЧКИ ПРОБЛЕМ

Репродукција трајекторије жељеног облика је од посебне важности посматрано са аспекта успешне реализације унутрашњег транспорта материјала у технолошком окружењу 21. века [1]. Популарно решење је примена концепта учења демонстрацијом у коме учитељ (човек или други робот) „указује“ на модел успешног понашања робота. Другим речима, жељене трајекторије робота се најпре демонстрирају од стране оператора (човека-демонстратора), а затим се испитује валидност забележених управљачких команди. С обзиром на различите нелинеарности које постоје приликом управљања роботских система (од несавршености израде појединих компонената до неодређености услед поремећаја и грешака у подсистемима робота), неопходно је извршити оптимизацију ових управљачких величина. У циљу одређивања оптималне трајекторије робота у окружењу, развијен је биолошки инспирисан алгоритам оптимизације који припада научној области *теорије ројева* (енгл. *Swarm intelligence*) [2]. Нови интелигентни систем управљања на бази метахеуристичког алгоритма тестиран је за више различитих трајекторија, а резултати указују да се наведени биолошки инспирисани алгоритми могу успешно користити у домену машинског учења и репродукције сложеног понашања мобилног робота.

На самом почетку извештаја представљене су теоријске основе проблема. У трећем поглављу, описан је развијени емпиријски управљачки систем на бази метахеуристичких алгоритама за решавање проблема репродукције комплексних трајекторија мобилног робота. Суштина техничког решења представљена је у четвртом делу извештаја. На крају извештаја дата је експериментална верификација предложеног управљачког система, као и правци даљих истраживања која ће се спроводити у оквиру актуелног пројекта технолошког развоја под називом „Иновативни приступ у примени интелигентних технолошких система за производњу делова од лима заснован на еколошким принципима” (евиденциони број *TP-35004*).

¹ Истраживач сарадник, Универзитет у Београду-Машински факултет, mmitic@mas.bg.ac.rs

² Научни сарадник, Иновациони центар Машинског факултета у Београду, nvukovic@mas.bg.ac.rs

³ Асистент, Универзитет у Београду-Машински факултет, mmpetrovic@mas.bg.ac.rs

⁴ Асистент, Универзитет у Београду-Машински факултет, jpetronijevic@mas.bg.ac.rs

⁵ Редовни професор, Универзитет у Београду-Машински факултет, zmiljkovic@mas.bg.ac.rs

⁶ Истраживач сарадник, „ECOLAB Hygiene“, д.о.о., Београд, atlant@ptt.rs

Теоријске поставке биолошки инспирисаних алгоритама оптимизације и парадигме машинског учења демонстрацијом

У општем случају, теорија ројева представља скупа математичко-алгоритамских процедура које се базирају на колективној интелигенцији скупа појединачних јединки [3,4]. Циљ различитих техника ове теорије је проналажење оптималног решења изабраног проблема. Алгоритми на бази ројева су најчешће инспирисани социјалним понашањем јединки јата риба, птица, мрав и др. У већини приступа колективно деловање роја зависи од свих чланова, с тим да се фаворизује понашање које је глобално најповољније. Другим речима, свака јединка добија информације од својих суседа о ваљаности својих акција, док је истовремено будуће напредовање засновано на претходним сазнањима целокупног роја. Овакав приступ у оптимизацији омогућава еволутивно (итеративно) напредовање свих чланова скупа, с тим да су перформансе алгорита оцењене према науспешнијим јединкама.

Метахеуристички алгоритам имплементиран у оквиру хибридног система управљања базира се на понашању свитаца у колонији. Алгоритам оптимизације колонијом свитаца развио је професор Јанг (*Yang*) са Универзитета Кембриџ у Великој Британији 2007. године [5,6]. Инспирисан комуникацијом између јединки у роју током процеса груписања ради проналажења хране и парања. Светлост коју емитију свици уједно представља и упозорење у случају настанка опасности односно присуства предатора. Познато је да је јачина светлости два извора обрнуто пропорционална квадрату растојању између њих ($I \approx 1/r^2$), што представља погодну чињеницу при разматрању математичког описа ове појаве. Истовремено, апсорбција светлости у ваздуху се не може занемарити при одређивању јачине сигнала успостављене између два емитера светлости, односно два члана исте колоније. На основу овога може се извести израз за јачину светлости у зависности од растојања између два извора светлости:

$$I(r) = I_0 \cdot e^{-\gamma r^2} \quad (1)$$

где је: r поменуто растојање, I_0 почетна јачина светлости коју емитију два извора светлости, γ коефицијент апсорбције ваздуха. Како би се ова релација повезала са понашањем колоније свитаца, неопходно је увести следеће претпоставке:

- Сви елементи колоније се понашају исто, без обзира на пол и године старости.
- Привлачност (енгл. *Attractiveness*) између две јединке је директно пропорционална јачини светлости коју оне емитију, а обрнуто пропорционална растојању између њих. Члан колоније који емитије мању количину светлости се креће ка јединки која је већи емитер, а у случају непостојања јаче светлости свитац се креће у произвољном правцу (енгл. *Random*).
- Јачина светлости појединачне јединке колоније зависи од проблема оптимизације; нпр. у случају оптимизације нелинеарне функције, величина I је пропорционална тродимензионалном облику те нелинеарности.

На основу ових претпоставки сада је могуће усвојити израз за параметар привлачности појединачних елемената колоније. Аналогно са једначином (1), привлачности свитаца је одређена релацијом:

$$\beta = \beta_0 \cdot e^{-\gamma r^2}, \quad (2)$$

која се за одређену класу проблема може апроксимирати помоћу [6]:

$$\beta = \frac{\beta_0}{1 + \gamma r^2}. \quad (3)$$

Растојање између две јединке одређено је помоћу Еуклидске норме преко:

$$r_{ij} = \|x_i - x_j\| = \sqrt{\sum_{k=1}^d (x_{i,k} - x_{j,k})^2}, \quad (4)$$

где $x_{i,k}$ и $x_{j,k}$ представљају k -ту просторну координату i -тог и j -тог члана колоније, респективно. У случају дводимензионалног простора, растојање r_{ij} се израчунава као:

$$r_{ij} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2}. \quad (5)$$

Коначно, може се формирати израз за промену положаја i -тог свица у правцу пораста јачине светлости (у правцу јединке j):

$$x_i = x_i + \beta_o e^{-\gamma r^2} + \alpha \varepsilon_i, \quad (6)$$

где α представља фактор случајности (усваја се из интервала $[0, 1]$ и може се експоненцијално смањивати у току процеса оптимизације), ε_i случајни број (енгл. *Random*) одабран према Гаусовој или униформној расподели. У најједноставнијем случају, параметар ε_i се може заменити једначином:

$$\varepsilon_i = \text{random}(0,1) - 0,5. \quad (7)$$

Псеудокод алгоритма оптимизације колонијом свитаца дат је у табели 1.

Табела 1. Псеудокод алгоритма оптимизације колонијом свитаца	
1.	Иницијализација броја чланова колоније свитаца, почетне јачине светлости сваког члана (I_i), и коефицијента апсорбције γ
2.	Почетак <i>итеративног</i> поступка (<i>while max_num_iteration</i>):
3.	За сваку јединку у колонији - „спољашња“ петља (<i>for each firefly_i</i>):
4.	За сваку јединку у колонији - „унутрашња“ петља (<i>for each firefly_j</i>):
5.	Израчунати растојање између свих јединки r_{ij}
6.	Ако је $I_i < I_j$, израчунати привлачност β према изразу (7.8) и променити положај свица i у правцу свица j
7.	Одредити нову вредности параметара α
8.	Затварање „унутрашње“ петље (<i>end_for_i</i>)
9.	Затварање „спољашње“ петље (<i>end_for_j</i>)
10.	Одређивање најбољег резултата целокупне колоније (<i>end_while</i>)
11.	Меморисање оптималног резултата (највеће вредности јачине светлости) и оцена перформанси алгоритма

Оптимизација ројем честица припада тзв. *популизационим техникама* (енгл. *Population algorithms*) вештачке интелигенције код којих се јединке „крећу“ кроз простор могућих решења у потрази за глобалним оптимумом [3,7]. Сваком члану роја неопходно је придружити информацију о његовој брзини и положају у хиперпростору $\mathbb{R}^n$. Истовремено, јединке памте и два параметра који описују деловање групе: (i) своје најбоље решење, и (ii) најбоље решење свих честица (глобално најбоље решење). Како би се убрзала конвергенција ка оптималном решењу, у неким случајевима се информација о глобално најповољнијем понашању замењује најбољим деловањем n честица у околини разматране јединке. Другим речима, најпре је неопходно одредити суседне чланове посматране честице, а затим израчунати најбоље решење те групе. Предност оваквог модификованог

приступа оптимизацији је смањење вероватноће „уласка“ у локални оптимум, док недостатак представља значајно повећање времена конвергенције.

Као што је наговештено, јединка одређује свој наредни положај у простору решења на основу свог тренутног положаја и тренутне брзине. Вредност брзине зависи од тренутног положаја јединке, најбољег положаја јединке до тог тренутка, као и (глобално) најбољег положаја свих чланова роја. Јасно је да будуће понашање посматраног члана зависи од његових когнитивних способности, као и од деловања целог роја. Битан елемент овог алгоритма је и *фактор интуиције* јединки, који је математички моделиран увођењем случајних бројева из интервала $[0\ 1]$. Овај параметар омогућава „прескакање“ локалих оптимума и бржу претрагу простора R^n . Наредни положај и брзина појединачног члана дефинисани су следећим релацијама:

$$x_{n+1}^{(i)} = x_n^{(i)} + v_{n+1}^{(i)} \quad (8)$$

$$v_{n+1}^{(i)} = w_n \cdot v_n^{(i)} + c_1 \cdot r_1 \cdot (p_{best}^{(i)} - x_n^{(i)}) + c_2 \cdot r_2 \cdot (g_{best} - x_n^{(i)}) \quad (9)$$

где је: $x_n^{(i)}$ тренутни положај i -те јединке, $x_{n+1}^{(i)}$ наредни положај i -те јединке, $p_{best}^{(i)}$ најбољи положај i -те јединке, g_{best} глобално најбољи положај (свих) јединки, $v_i(t)$ тренутна брзина i -те јединке, $v_{n+1}^{(i)}$ наредна брзина i -те јединке, w_n параметар инерције (усваја се из интервала $[0,9\ 1,2]$), r_1 и r_2 случајно изабрани бројеви из интервала $[0\ 1]$, c_1 и c_2 коефицијенти самоспознаје честице и глобалне важности, следствено (усвајају се из интервала $[1,8\ 2,2]$). Псеудокод овог оптимизационог алгоритма дат је у табели 2 [7].

Табела 2. Псеудокод алгоритма оптимизације ројем честица	
1.	Иницијализација параметара c_1 , c_2 , r_1 , r_2 , w_n
2.	Одабир положаја $x_n^{(i)}$ и брзине $v_n^{(i)}$ за n јединки
3.	Одређивање глобално најбољег решења g_{best}
4.	Почетак <i>итеративног</i> поступка (<i>while max_num_iteration</i>):
5.	За сваку појединачну јединку у роју (<i>for each particle</i>):
6.	Израчунавање брзине честице према изразу (9)
7.	Израчунавање положаја честице према изразу (8)
8.	Одређивање најбољег положаја за сваку од честица (<i>end_for</i>)
9.	Одређивање глобално најбољег положаја (<i>end_while</i>)
10.	Меморисање најбољег резултата и оцена перформанси алгоритма

Алгоритам оптимизације колонијом слепих мишева развијен је 2010. година [8]. Основна идеја се базира на подешавању фреквенције ехолокације сваке појединачне јединке у роју. Као и у случају алгоритма оптимизације ројем честица, најпре је неопходно одредити тренутну позицију и брзину индивидуе:

$$f_i = f_{\min} + (f_{\max} - f_{\min})\beta$$

$$v_i^t = v_i^{t-1} + (x_i^{t-1} - x^*)f_i \quad (10)$$

$$x_i^t = x_i^{t-1} + v_i^t$$

где је: f_i фреквенција, β случајна променљива по Гаусу, x_i^t тренутни положај i -те јединке, x_i^{t-1} претходни положај i -те јединке, v_i^t тренутна брзина i -те јединке, v_i^{t-1} претходна брзина i -те јединке, x^* глобално најбоље решење. На крају, нова позиција јединке рачуна се преко:

$$x_{new} = x_{old} + \varepsilon A^t \quad (11)$$

где је: ε случајна променљива из опсега $[-1, 1]$, а A параметар звучности. Псеудокод овог алгоритма дат је у табели 3 [8].

Табела 3. Псеудокод алгоритма оптимизације колонијом слепих мишева	
1.	Иницијализација параметара f_i, A, r_i
2.	Одабир положаја x_i и брзине v_i за n јединки
3.	Почетак итеративног поступка (<i>while max_num_iteration</i>):
4.	Одреди нова решења према једначини (10)
5.	Ако важи услов $\text{rand} > 0.5$ (<i>if rand > r_i</i>)
6.	Одреди најбоље решење према (11)
7.	Крај услова (<i>end_if</i>)
8.	Ако важе услови $\text{rand} < A_i$ и $f(x_i) < f(x^*)$ (<i>if услов</i>)
9.	Усвоји нова решења, повећај r_i и смањи A_i
10.	Крај услова (<i>end_if</i>)
11.	Рангирај решења и нажи тренутно глобално најбоље x^*
12.	Завршетак свих итерација (<i>end_while</i>)
13.	Меморисање најбољег резултата и оцена перформанси алгоритма

У општем случају разликујемо три модула машинског учења демонстрацијом: модул демонстрација (енгл. *Demonstration Module*), модул машинског учења (енгл. *Learning Module*), и модул научених (оптималних) акција (енгл. *Drive Modul*) интелигентног агента. Модул демонстрација подразумева запис сензорских вредности неопходних за успешно извршавање постављеног задатка. Роботски систем у овом модулу меморише сензорске информације и извршава њима одговарајуће унапред дефинисане акције. Модул машинског учења подразумева процес нелинераног пресликавања скупа улазних података (очитавања са спољашњих и/или унутрашњих сензора) у скуп излазних података (скуп акција робота). Овај модел у описаном техничком решењу представља метахеуристички алгоритам оптимизације колонијом свитаца. Модул научених акција обухвата извршавање сваке од акција и израчунавање грешке са аспекта успешности нелинеарног пресликавања скупова дефинисаних у претходном модулу. Скуп акција са најмањом израчунавом грешком представљаће скуп оптималних акција при извршавању разматраног задатка. Детаљније о машинском учењу демонстрацијом могуће је видети у [9].

3. ПОСТОЈЕЋЕ СТАЊЕ У СВЕТУ

Теорија ројева (енгл. *Swarm intelligence*) у домену мобилне роботике се најчешће примењује за решавање проблема навигације. Један од првих алгоритама у овој области користи технику оптимизације колонијом мравља (енгл. *Ant colony optimization*) у циљу планирања оптималне путање у окружењу [10]. Иста метода имплементирана је у хибридни управљачки алгоритам како би се одредило глобално и локално решење поменутог проблема [11]. Истраживање представљено у [12] показало је да је ову технику оптимизације могуће користити и за генерисање оптималних фази управљачких система. Комбиновањем система вештачких неуронских мрежа и методе оптимизације роја честица (енгл. *Particle swarm optimization*) развијен је алгоритам навигације нехолономног мобилног робота у статичком окружењу [13]. Новом хибридном *еволуционом* техником на бази роја

честица извршена је оптимизација фази система ради управљања мобилног робота у реалном времену [14]. Генетички алгоритми (енгл. *Genetic algorithms*) су такође заступљени у области когнитивне роботике, и најчешће су коришћени за планирање путање [15], навигацију [16], и/или локализацију мобилног робота [17]. Међутим, у стручној и научној литератури из ове области постоји несигнификантан број приказа нових биолошки инспирисаних алгорита при управљању роботских система [18]. У оквиру овог техничког решења представљен је развијени хибридни управљачки систем мобилног робота који се заснива на искуству и новим методама оптимизације [18].


4. СУШТИНА ТЕХНИЧКОГ РЕШЕЊА

Репродукција жељене трајекторије мобилног робота решена је применом машинског учења демонстрацијом и биолошки инспирисаних алгорита оптимизације. Три независна модула учења демонстрацијом имплементирана су у оквиру схеме управљања мобилног робота. Модул демонстрација и модул научених акција дефинисани су на исти начин као и код хибридног система управљања који је детаљно описан у техничком решењу [2, 19]. У модулу машинског учења, проблем прескликавања улазног у излазни домен трансформисан је у проблем оптимизације. Познато је да се мобилни робот најчешће понаша другачије у различитим итерацијама са истим вредностима управљања. Ова појава је последица несавршености механичких подсистема мобилног робота, као и реалних услова у техничком окружењу (утицај подлоге, немерљивих поремећаја, итд.). У циљу елиминације ових неповољности, описани биолошки инспирисани алгоритми су имплементирани у хибридни систем управљања односно у модул учења. Вредности команди актуаторима су модификоване тако да подлежу Гаусовој и/или униформној расподели са различитим вредностима варијанси. Овако усвојена управљања су затим тестирана на мобилном роботу у реалном окружењу како би се потврдила чињеница да једној вредности разлике положаја објекта одговарају различите вредности управљачких команди. Оптимизација помоћу биолошки инспирисаног алгорита подразумева проналажење секвенце управљачких команди која проузрокују минималну грешку на крају кретања (у последњем положају) мобилног робота.


Навигација робота у технолошком окружењу у оквиру овог техничког решења односи се на репродукцију трајекторије жељеног облика. Као што је речено, несавршености актуатора робота и услови у технолошком окружењу имају велики утицај на реализацију жељеног понашања робота. У циљу превазилажења ових проблема при управљању робота, оптимална трајекторија је одређена применом концепта машинског учења демонстрацијом и биолошки инспирисаних алгорита оптимизације. Модул демонстрација обухвата скуп трајекторија неопходних за израчунавање оптималног кретања робота. Трајекторије су генерисане управљањем мобилног робота у технолошком окружењу помоћу команди које подлежу Гаусовој и/или униформној расподели. Након меморисања управљачких величина у овом модулу, започиње процес учења применом алгорита оптимизације. Перформансу циља оптимизације представља минимална грешка у позицији и оријентацији робота у крајњем положају. Модул научених акција подразумева поступак тестирања кретања мобилног робота, користећи команде које су добијене алгоритмом оптимизације. Перформансе робота оцењене су на основу успешности репродуковања жељене трајекторије у статичком окружењу.

5. ПРИКАЗ РЕЗУЛТАТА ПРИМЕНЕ

У оквиру овог дела техничког решења приказани су резултати експеримента интелигентног управљања мобилног робота у домену репродукције комплексних трајекторија. Такође, извршено је и поређење биолошки инспирисаних алгорита за различит број јединки у роју [18]. Прва фаза експеримента обухвата прикупљање управљачких команди за скуп са различитим бројем трајекторија жељеног облика. Управљања су одређена тако да подлежу Гаусовој и униформној расподели са варијансом од 10. Ове управљачке команде су дате на слици 1, где је уочљива разлика између њих при реализацији трајекторије идентичног жељеног облика [18]. Слика 2 приказује жељене трајекторије које су настале имплементацијом управљачких команди датих на слици 1. Карактеристике ових трајекторија, као и почетни и жељени положај робота, представљене су у табели 4.



Слика 1. Управљачке команде левог (горе) и десног (доле) точка: (а) трајекторија T1, (б) трајекторија T2. Итерација управљања је дата на x-оси, а вредност управљања на y-оси.



Слика 2. Демонстрације трајекторија за репродукцију: (а) трајекторија T1, (б) трајекторија T2.

Табела 4. Карактеристике трајекторија за репродукцију				
Трајекторија	Почетни положај	Жељени положај	Укупан бр. управљачких команди	Стандардна девијација σ
T1	$\begin{bmatrix} x \\ y \\ \theta \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix}$	$\begin{bmatrix} x & y & \theta \end{bmatrix}^T = \begin{bmatrix} 30.4166 & 0 & -180 \end{bmatrix}^T$	83	10
T2		$\begin{bmatrix} x & y & \theta \end{bmatrix}^T = \begin{bmatrix} 88.2469 & 65.4825 & -40.54 \end{bmatrix}^T$	123	

За циљ оптимизације усвојен је критеријум најмање грешке на крају кретања мобилног робота. Основни параметри алгоритама усвојени су према препорученим вредностима. Параметри FA усвојени су на следећи начин: $\alpha = 0.2$, $\gamma = 0.97$, $\beta_0 = 1$. PSO има $\alpha = \beta = 0.2$, док је за BA усвојено да важи $A = r_i = 0.5$. За све алгоритме важи да је број јединки 30 и максималан број итерација 1000. У табели 5, табели 6 и табели 7 дати су компаративни резултати за обе трајекторије [18]. Као критеријум оцене перформанси алгорита усвојен је корен средње квадратне грешке у положају мобилног робот у последњој итерацији:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (p - p_{des})^2} \quad (12)$$


где је: $p = [x \ y \ \theta]^T$ остварени, а $p_{des} = [x \ y \ \theta]_{des}^T$ жељени положај робота.

Табела 5. Перформансе биолошки инспирисаних алгоритама оптимизације са 5 јединки у колонији			
Трајекторија	PSO	BA	FA
T1	RMSE_best = 0.6841 RMSE_worst = 5.8877 RMSE_average = 2.2677 Median=2.0300 Std=1.2801	RMSE_best = 0.3328 RMSE_worst = 3.8330 RMSE_average = 1.4196 Median=1.1846 Std=0.9465	RMSE_best = 0.2666 RMSE_worst = 2.9004 RMSE_average = 1.3392 Median=1.2804 Std=0.6830
T2	RMSE_best = 0.4527 RMSE_worst = 4.7346 RMSE_average = 1.6431 Median=1.6075 Std=0.8231	RMSE_best = 0.1754 RMSE_worst = 3.0516 RMSE_average = 1.4502 Median= 1.4886 Std= 0.7598	RMSE_best = 0.0239 RMSE_worst = 1.9195 RMSE_average = 0.9243 Median=0.8982 Std= 0.5100

Табела 6. Перформансе биолошки инспирисаних алгоритама оптимизације са 15 јединки у колонији			
Трајекторија	PSO	BA	FA
T1	RMSE_best = 0.7316 RMSE_worst = 4.6731 RMSE_average = 1.7773 Median=1.4321 Std=1.0469	RMSE_best = 0.1341 RMSE_worst = 1.4450 RMSE_average = 0.7333 Median=0.7305 Std= 0.3550	RMSE_best = 0.1182 RMSE_worst = 1.3726 RMSE_average = 0.6205 Median= 0.5914 Std=0.3084
T2	RMSE_best = 0.4874 RMSE_worst = 3.4781 RMSE_average = 1.7961 Median=1.7954 Std=0.8458	RMSE_best = 0.2559 RMSE_worst = 1.7833 RMSE_average = 0.7270 Median= 0.7036 Std= 0.4418	RMSE_best = 0.0810 RMSE_worst = 1.5284 RMSE_average = 0.7157 Median=0.6407 Std=0.3253

Табела 7. Перформансе биолошки инспирисаних алгоритама оптимизације са 30 јединки у колонији			
Трајекторија	PSO	BA	FA
T1	RMSE_best = 0.3864 RMSE_worst = 5.3770 RMSE_average = 1.7801 Median=1.2548 Std=1.2551	RMSE_best = 0.1777 RMSE_worst = 1.3603 RMSE_average = 0.5617 Median=0.5329 Std=0.2933	RMSE_best = 0.0347 RMSE_worst = 1.1117 RMSE_average = 0.4602 Median=0.4768 Std=0.2442
T2	RMSE_best = 0.5961 RMSE_worst = 4.4179 RMSE_average = 1.9559 Median=1.7916 Std=1.0046	RMSE_best = 0.0755 RMSE_worst = 0.8624 RMSE_average = 0.5265 Median=0.5618 Std=0.2026	RMSE_best = 0.0511 RMSE_worst = 1.0000 RMSE_average = 0.4150 Median= 0.3206 Std= 0.2801

Резултати приказани у табели 5, табели 6 и табели 7 недвосмислено указују на то да је алгоритама оптимизације колонијом свитаца (FA) најбоље решење. Независно од величине колоније, FA је проузроковао минималну RMSE грешку у последњем положају мобилног робота [18]. Истовремено, статистичке величине медијана и стандардна девијација укажују да FA представља оптимално решење за дати проблем. С обзиром на ове чињенице, FA је имплементиран за репродукцију трајекторија датих у табели 4. На слици 3 приказани су резултати репродукције жељених трајекторија. База мобилног робота и његова оријентација, у свакој итерацији, означене су плавом и црвеном бојом, респективно. Уочљиво је да робот успешно репродукује жељену трајекторију, што је директна последица успешног учења управљачких команди на бази FA алгорита. Финални положај мобилног робота одговара жељеном положају чиме се потврђује робустност развијеног интелигентног система са становишта управљања у условима постојања мерљивих и немерљивих поремећаја [18].



Слика 3. Резултати алгорита оптимизације колонијом свитаца приликом репродукције различитих трајекторија: (а) трајекторија T1, (б) трајекторија T2.

6. ЗАКЉУЧАК

Техничко решење (нова метода) се односи на решавање проблема управљања интелигентног мобилног робота применом емпиријске управљачке теорије на бази биолошки инспирисаних алгоритама оптимизације и машинског учења демонстрацијом. Развијена су три различита приступа поступку оптимизације: (i) алгоритам оптимизације колонијом свитаца (енгл. *Firefly Algorithm-FA*), (ii) алгоритам оптимизације ројем честица (енгл. *Particle Swarm Optimization-PSO*), и (iii) алгоритам оптимизације колонијом слепих мишева (енгл. *Bat Algorithm-BA*). Ови алгоритми имплементирани су у оквиру машинског учења демонстрацијом у циљу решавања проблема управљања мобилног робота приликом репродукције жељене трајекторије [18]. Управљачке команде мобилног робота за реализацију више различитих трајекторија жељеног облика меморисане су у модулу демонстрација. Управљања су дефинисана тако да подлежу Гаусовој и униформној расподели са вредношћу варијансе од $\sigma = 10$. Метода оптимизације је затим искоришћена како би се одредила оптимална трајекторија робота у модулу машинског учења. Циљ оптимизације представља генерисање оптималне секвенце управљачких команди, тако да грешка позиције и оријентације мобилног робота, на крају кретања, буде минимална. Поређењем наведених алгоритама закључује се да *FA* метода даје најбоље резултате (**табела 5**, **табела 6** и **табела 7**). Резултати су потврдили и то да мобилни робот репродукује оптималну трајекторију у реалном времену (**слика 3**), односно да се алгоритам оптимизације може успешно корисити ради одређивања оптималног понашања робота [18].

Наставак развоја интелигентног емпиријског управљачког система у оквиру планираних активности актуелног пројекта технолошког развоја (евид. бр. *TP35004*) обухватаће следеће правце:

- Имплементацију биолошки инспирисаних алгоритама базираних на хаотичним мапама [20,21,22] у домену машинског учења и репродукције жељене трајекторије мобилног робота.
- Поређење и упоредну анализу других метахеуристичких метода оптимизације у оквиру емпиријског управљања мобилног робота.
- Анализу могућности имплементације биолошки инспирисаних алгоритама при оптимизацији функција припадности (енгл. *Membership functions*) фази управљачког система интелигентног мобилног робота.

ЛИТЕРАТУРА

- [1] Russel, S., Norvig, P., Artificial intelligence: a modern approach, 3rd Edition, Prentice Hall, 2010.
- [2] Митић, М., Миљковић, З., Вуковић, Н., Лазаревић, И., Праћење жељене трајекторије и визуелно навођење мобилног робота у технолошком окружењу на бази биолошки инспирисаног метахеуристичког алгоритма (нова метода развијана у пројекту *TP-35004* МПНиТР Владе Републике Србије), 2013.
- [3] Kennedy, J. F., Kennedy, J., Eberhart, R. C., Swarm intelligence, Morgan Kaufmann, 2001.
- [4] Kochenberger, G. A. (Ed.), Handbook in Metaheuristics, Springer, 2003.
- [5] Yang, X. S., Firefly algorithms for multimodal optimization. In: Stochastic algorithms: foundations and applications, Springer Berlin Heidelberg, pp. 169-178, 2009.
- [6] Yang, X. S., Nature-inspired metaheuristic algorithms, 2nd Edition, Luniver Press, 2010.
- [7] Bonabeau, E., Dorigo, M., Theraulaz, G., Swarm intelligence: from natural to artificial systems (Vol. 4), New York: Oxford University press, 1999.
- [8] Yang, X. S., A new metaheuristic bat-inspired algorithm, Nature inspired cooperative strategies for optimization (NICSO 2010), pp. 65-74, 2010.
- [9] Argall B., Chernova S., Veloso M., Browning, B., A survey of robot learning from demonstration, Robotics and Autonomous Systems, Vol. 57, No. 5, pp. 469-483, 2009.
- [10] Fan, X., Luo, X., Yi, S., Yang, S., Zhang, H., Optimal path planning for mobile robots based on intensified ant colony optimization algorithm, In: Robotics, Intelligent Systems and Signal Processing, Vol. 1, pp. 131-136, 2003.
- [11] Mei, H., Tian, Y., Zu, L., A hybrid ant colony optimization algorithm for path planning of robot in dynamic environment, International Journal of Information Technology, Vol. 12, No. 3, pp. 78-88, 2006.

- [12] Garcia, M. A., Montiel, O., Castillo, O., Sepúlveda, R., Melin, P., Path planning for autonomous mobile robot navigation with ant colony optimization and fuzzy cost function evaluation, *Applied Soft Computing*, Vol. 9, No. 3, 1102-1110, 2009.
- [13] Li, Y., Chen, X., Mobile robot navigation using particle swarm optimization and adaptive NN, In: *Advances in Natural Computation*, pp. 628-631, Springer Berlin Heidelberg, 2005.
- [14] Juang, C. F., Chang, Y. C., Evolutionary-group-based particle-swarm-optimized fuzzy controller with application to mobile-robot navigation in unknown environments, *IEEE Transactions on Fuzzy Systems*, Vol. 19, No. 2, 379-392, 2011.
- [15] Han, W. G., Baek, S. M., Kuc, T. Y., Genetic algorithm based path planning and dynamic obstacle avoidance of mobile robots, In: *IEEE International Conference on Computational Cybernetics and Simulation*, Vol. 3, pp. 2747-2751, 1997.
- [16] Ram, A., Boone, G., Arkin, R., Pearce, M., Using genetic algorithms to learn reactive control parameters for autonomous robotic navigation, *Adaptive Behavior*, Vol. 2, No. 3, 277-305, 1994.
- [17] Moreno, L., Armingol, J. M., Garrido, S., De La Escalera, A., Salichs, M. A., A genetic algorithm for mobile robot localization using ultrasonic sensors, *Journal of Intelligent and Robotic Systems*, Vol. 34, No. 2, 135-154, 2002.
- [18] Mitić, M., Miljković, Z., Bio-inspired Approach to Learning Robot Motion Trajectories and Visual Control Commands, *Journal Expert Systems with Applications* (ISSN 0957-4174), Vol. 42 Issue: 5, pp. 2624 - 2637, Elsevier, 1 April 2015; (Available online: 13 November 2014 as DOI: 10.1016/j.eswa.2014.10.053 <http://www.sciencedirect.com/science/article/pii/S0957417414006940>), (Science Citation Index-Web of Science® – IF = 1,965 (2013) → M21; извор KoBSON)
- [19] Митић, М., Миљковић, З., Вуковић, Н., Бабић, Б., Емпиријско управљање интелигентног мобилног робота на бази машинског учења демонстрацијом и хомографије добијене од некалибрисане камере (нова метода развијана у пројекту ТР-35004 МПНитР Владе Републике Србије), 2012.
- [20] Coelho, L, Mariani, V. C., Use of chaotic sequences in a biologically inspired algorithm for engineering design optimization, *Expert Systems with Applications*, Vol. 34, pp. 905–913, 2008.
- [21] Gandomi, A. H., Yang, X. S., Talatahari, S., Alavi, A. H., Firefly algorithm with chaos, *Communications in Nonlinear Science and Numerical Simulation*, Vol. 18, pp. 89-98, 2013.
- [22] Петровић, М., Митић, М., Вуковић, Н., Миљковић, З., Оптимизација флексибилних технолошких процеса применом алгорита базираног на интелигенцији роја и теорији хаоса, 39. ЈУПИТЕР Конференција, 35. симпозијум „НУ-РОБОТИ-ФТС“, Зборник радова, CD, стр. 3.122-3.129, Београд, 28. октобар 2014.

Одлуком Наставно-научног већа Машинског факултета у Београду бр. 3127/2 од 11.12.2014. године именовани смо за рецензенте нове методе под називом „Репродукција комплексних трајекторија мобилног робота на бази биолошки инспирисаних алгоритама” аутора: др Марко Митић, истраживач сарадник, др Најдан Вуковић, научни сарадник, асист. Милица Петровић, дипл. инж. маш., асист. Јелена Петронијевић, дипл. инж. маш., проф. др Зоран Миљковић и мр Иван Б. Лазаревић, дипл. инж. маш.. На основу предлога и након анализе методе подносимо следећи:

ИЗВЕШТАЈ

Нова метода (М85) под називом „Репродукција комплексних трајекторија мобилног робота на бази биолошки инспирисаних алгоритама” представљена је на 11 страница А4 формата, коришћењем Times New Roman фонта величине 11 pt, једноструког прореда. Опис методе садржи 12 једначина, 3 слике и 7 табеларних приказа резултата примене нове методе представљених у следећих шест тематских целина, уз списак коришћене литературе:

1. Област на коју се техничко решење односи,
2. Технички проблем,
3. Постојеће стање у свету,
4. Суштина техничког решења,
5. Приказ резултата примене,
6. Закључак.

Техничко решење припада области производних технологија и директно се односи на решавање проблема репродукције комплексне трајекторије нехолономног мобилног робота применом емпијске управљачке теорије. Развијени управљачки систем обухвата интеграцију интелигентног система базираног на биолошки инспирисаним метахеуристичким алгоритмима оптимизације и емпијски прикупљеним сензорским информацијама, а који је базиран на машинском учењу демонстрацијом.

У оквиру другог поглавља образложен је технички проблем и дате су теоријске основе система управљања за проблем репродукције изабране трајекторије робота. У основим цртама представљене су теоријске поставке управљачких система на бази три различита биолошки инспирисана алгорита: (i) алгоритам оптимизације колонијом свитаца (енгл. *Firefly Algorithm-FA*), (ii) алгоритам оптимизације ројем честица (енгл. *Particle Swarm Optimization-PSO*), и (iii) алгоритам оптимизације колонијом слепих мишева (енгл. *Bat Algorithm-BA*). Такође, описана су три основна модула машинског учења демонстрацијом који су, заједно са изабраним алгоритмом оптимизације, коришћени за побољшање конвергенције развијеног емпијског алгоритма ка оптималном решењу. Модул демонстрација подразумева запис управљачких команди неопходних за успешно извршавање постављеног задатка; модул машинског учења односи се на процес нелинераног пресликавања скупа улазних података (управљачке команде неопходне за реализацију различитих трајекторија) у скуп излазних података (скуп акција робота); модул научених акција обухвата извршавање сваке од акција и израчунавање грешке са аспекта успешности нелинеарног пресликавања скупова дефинисаних у претходном модулу. Такође, дата је математичка подлога свих наведених алгоритама уз навођење псеудокода и референтне литературе.

У трећем поглављу наведено је постојеће стање у свету. Иако не постоји много примера имплементације биолошки инспирисаних алгоритама у домену учења трајекторија мобилног робота, актуелни резултати истраживања су детаљно описани. Девет референтних научних публикација је издвојено, приказујући релевантна истраживања од 1994. године до данас. Описани су научни радови који решавају проблем репродукције жељене трајекторије користећи технике оптимизације које су базиране на алгоритму мравље колоније, генетичком алгоритму, као и методи оптимизације ројем честица.

Четврто поглавље садржи суштину техничког решења приказану кроз концепцијско решење емпијског управљачког система. Несавршености актуатора робота и услови у технолошком окружењу имају велики утицај на реализацију жељеног понашања робота. У циљу


превазилажења ових проблема при управљању робота, оптимална трајекторија је одређена применом концепта машинског учења демонстрацијом и биолошки инспирисаних алгоритама оптимизације. Трајекторије су генерисане управљањем мобилног робота у окружењу помоћу команди које подлежу Гаусовој и/или униформној расподели. Након меморисања управљачких величина у овом модулу, започиње процес учења применом изабраног алгорита оптимизације (*FA*, *PSO* или *BA*). Модул научених акција подразумева поступак тестирања кретања мобилног робота, користећи команде које су добијене алгоритмом оптимизације. На крају, анализирају се перформансе алгорита и оцењује се успешност репродуковања изабране комплексне трајекторије.


Пето поглавље приказује експерименталну верификацију развијеног управљачког система на бази биолошки инспирисаних алгоритама оптимизације. Извршено је поређење *FA*, *PSO* и *BA* алгорита оптимизације при реализацији две различите оптималне трајекторије. Такође, перформансе ових алгоритама су анализирани за различит број јединки у колонији (табела 5, табела 6 и табела 7). Најмања *RMSE* грешка, медијана и стандардна девијација добијене су у случају *FA* технике оптимизације. Зато је овај алгоритам изабран као оптимално решење проблема машинског учења и репродукције жељене трајекторије (слика 3). Показано је и то да је могуће одредити такав скуп управљачких команди робота који обезбеђује минималну грешку позиције и оријентације мобилног робота на крају кретања. Са слике 3 је такође уочљиво да робот успешно репродукује жељену трајекторију целом дужином, што је директна последица успешног учења и генерисања управљачких команди на бази *FA* алгорита.

У оквиру закључка наглашена је предност развијеног емпиријског управљачког система у односу на позната постојећа решења. Потврђено је да нови емпиријски управљачки систем на бази биолошких алгоритама оптимизације карактеришу својства *флексибилности* (алгоритам управљања је могуће секвенцијално применити на више технолошких задатака) и *робустности* (није неопходно обезбедити додатну транспортну инфраструктуру у окружењу). Такође, у кратким цртама, представљени су правци будућих истраживања на актуелном пројекту технолошког развоја (евид. бр. TP35004). У складу са датом анализом предлога техничког решења, као именовани рецензенти дајемо следеће

МИШЉЕЊЕ

Аутори нове методе (**M85**) под називом „**Репродукција комплексних трајекторија мобилног робота на бази биолошки инспирисаних алгоритама**” су на јасан начин описали концепцијско решење управљања мобилног робота на бази емпиријске управљачке теорије, машинског учења демонстрацијом и биолошки инспирисаних алгоритама оптимизације. Резултати остварени применом ове нове методе указују на то да постоји очит допринос постојећем стању развоја, а потврђују и то да је омогућен ефикасан начин реализације машинског учења и репродукције комплексних трајекторија нехолономног мобилног робота у технолошком окружењу. На основу увида у предлог нове методе и остварене резултате предлажемо Наставно-научном већу Машинског факултета у Београду да се нова метода под називом „**Репродукција комплексних трајекторија мобилног робота на бази биолошки инспирисаних алгоритама**” прихвати као ново техничко решење.


Проф. др Мирко Ћапић
Универзитет у Крагујевцу
Факултет за машинство и грађевинарство у Краљеву


Доц. др Радиша Јовановић
Универзитет у Београду-Машински факултет



Београд, 19.01.2015. године

Предмет: Мишљење о реализацији пројекта „Иновативни приступ у примени интелигентних технолошких система за производњу делова од лима заснован на еколошким принципима“ (ТР-35004) у периоду 01.01.2014.-31.12.2014. (четврта година финансирања)

Пројектом су обухваћена два основна циља истраживања: одређивање параметара производње делова од лима и управљање унутрашњим транспортом материјала са акцентом на примени еколошких принципа који подразумевају уштеду енергије, материјала и средстава за подмазивање.

У овој истраживачкој години настала су два техничка решења – нове методе. Прва метода под називом „**Репродукција комплексних трајекторија мобилног робота на бази биолошки инспирисаних алгоритама**“ се односи на решавање комплексног проблема управљања интелигентног мобилног робота применом емпиријске управљачке теорије на бази биолошки инспирисаних алгоритама оптимизације и машинског учења демонстрацијом, и то тако да се управљачке команде мобилног робота користе за репродукцију више трајекторија жељеног облика у оквиру модула за демонстрацију, док се у модулу машинског учења врши имплементација метода оптимизације у циљу одређивања оптималне трајекторије робота.

У оквиру друге методе под називом „**Интегрисано пројектовање и терминирање оптималних флексибилних технолошких процеса базирано на мултиагентним системима и техникама вештачке интелигенције**“ решава се проблем генерисања оптималних планова терминирања применом мултиагентних система и техника вештачке интелигенције, конкретно биолошки инспирисаног алгорита на бази интелигенције роја честица и вештачких неуронских мрежа. Резултати остварени применом ове нове методе (генерисани оптимални планови терминирања) указују на то да постоји евидентан допринос у области интегрисаног пројектовања наведених производних функција, који се огледа како кроз боље искоришћење ресурса, тако и кроз смањење укупних трошкова.

Након увида у примењивост нових техничких решења (нових метода), која су проистекла као резултати истраживања у оквиру пројекта ТР35004, и на основу досадашње сарадње са реализаторима, компанија ФМП д.о.о. изражава задовољство спроведеним истраживањима и оствареним резултатима.

Генерални директор ФМП д.о.о.



Небојша Стојановић, дипл. маш. инж.

11000 Beograd, Jugoslovenska br. 2; Tel: 011 655 75 33, Fax: 011 655 75 73

www.fmp.co.rs

office@fmp.co.rs

Београд, 19. 01. 2015. године

Предмет: Мишљење о реализацији пројекта
„ИНОВАТИВНИ ПРИСТУП У ПРИМЕНИ ИНТЕЛИГЕНТНИХ
ТЕХНОЛОШКИХ СИСТЕМА ЗА ПРОИЗВОДЊУ ДЕЛОВА ОД
ЛИМА ЗАСНОВАН НА ЕКОЛОШКИМ ПРИНЦИПИМА“
Евиденциони број TP-35004

Након увида у резултате истраживања који су објављени и представљени на научним скуповима домаћег и међународног значаја, као и у примењивост новог техничког решења, и на основу досадашње сарадње са реализаторима, компанија OPTIX д.о.о. изражава задовољство спроведеним истраживањима и оствареним резултатима.



Генерални директор OPTIX д.о.о.

Др доц Драгомир Стаменковић, дипл. маш. инж.

УНИВЕРЗИТЕТ У БЕОГРАДУ
- МАШИНСКИ ФАКУЛТЕТ -
БРОЈ: 3127/3
ДАТУМ: 26.12.2014.

На основу захтева др Бојана Бабића, редовног професора Машинског факултета Универзитета у Београду, бр. 3127/1 од 03.12.2014. године и чл. 63. Статута Машинског факултета, Наставно-научно веће Машинског факултета на седници од 25.12.2014. године, донело је следећу


ОДЛУКУ

Прихвата се Техничко решење (М85) под насловом: „РЕПРОДУКЦИЈА КОМПЛЕКСНИХ ТРАЈЕКТОРИЈА МОБИЛНОГ РОБОТА НА БАЗИ БИОЛОШКИ ИНСПИРИСАНИХ АЛГОРИТАМА“ чији су аутори: др Марко Митић, истраживач сарадник, др Најдан Вуковић, научни сарадник, асист. Милица Петровић, дипл.инж.маш., асист. Јелена Петронијевић, дипл.инж.маш., проф. др Зоран Миљковић и мр Иван Лазаревић, дипл.инж.маш.

Одлуку доставити: Министарству просвете, науке и технолошког развоја РС, рецензентима и архиви Факултета ради евиденције.



2 Д Е К А Н
МАШИНСКОГ ФАКУЛТЕТА


Проф.др Милорад Милованчевић